

SVEUČILIŠTE U ZAGREBU
Fakultet strojarstva i brodogradnje

ZAVRŠNI RAD

Hrvoje Pinculić

Zagreb, 2015.

Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje

ZAVRŠNI RAD

**OBRADA EKSPERIMENTALNIH PODATAKA PROCESA
ZAKALJIVANJA PRIMJENOM OSREDNJAVAJUĆIH I
INTERPOLACIJSKIH FILTARA**

Voditelj rada:
Prof. dr.sc. Davor Zorc

Student:
Hrvoje Pinculić

Zagreb, 2015.

Izjavljujem da sam ovaj rad izradio samostalno, koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvala

Zahvaljujem se prof. dr. sc. Davoru Zorcu, mentoru ovoga rada, na stručnoj pomoći pri izradi ovog rada.

Zahvaljujem se doc. dr. sc. Danijelu Pavkoviću na informacijama od izuzetne važnosti za ovu temu.

Hrvoje Pinculić

Sažetak

Pri obradi bilo kakvih eksperimentalnih podataka vrlo često se javljaju različite smetnje koje otežavaju uspješnu interpretaciju mjernih rezultata. Rješenje tog problema je u samoj obradi tih podataka, tj. njihovom filtriranju, čime se postiže potiskivanje utjecaja smetnji na prihvatljivu razinu koja omogućuje kvalitetnu interpretaciju mjernih rezultata.

Zadatak ovog rada je pronalaženje optimalnog niskopropusnog filtra u formi usrednjavajućeg filtra s pomičnim vremenskim prozorom, odnosno filtra s konačnim trajanjem impulsnog odziva (engl. Finite Impulse Response, FIR). Pri tome se posebna pažnja posvećuje izboru težinskih koeficijenata otežane aritmetičke sredine unutar preddefiniranog prozora s ciljem postizanja najbržeg odziva uz istovremeno najniže razine šuma u filtriranom signalu. Odabrani FIR filter, zasnovan na težinskim koeficijentima prema polinomskoj Čebiševljevoj funkciji, upotrijebljen je za naknadnu obradu rezultata procesa zakaljivanja, karakteriziranih izraženim šumom kvantizacije zbog primjene analogno-digitalnog pretvornika 8-bitovne razlučivosti.

Tako obrađeni mjerni podaci poslužili su za poboljšanje prikaza brzine hlađenja izratka podvrgnutog procesu zakaljivanja, u odnosu na prikaz dobiven na izvorno snimljenim podacima. Sve programske rutine i korisničko sučelje za obradu podataka implementirani su u programskom paketu Matlab.

Sadržaj

Sažetak.....	I
Sadržaj.....	II
Popis slika.....	III
Popis tablica	V
Popis oznaka	V
1. Uvod.....	1
2. Signali	2
2.1.Podjela signala.....	2
2.1.1. Digitalni i analogni signali	3
2.2. Uzimanje uzoraka signala	4
2.2.1. Rezolucija	5
2.2.2. Kvantizacija.....	6
2.2.3. Nyquistov teorem.....	7
2.2.4. Analogni filtri.....	8
2.3.Digitalna obrada signala i filtriranje	9
2.3.1.Primjeri digitalne obrade signala	9
2.4. Digitalni filtri	11
2.4.1. Idealni filtri	11
2.4.2. Realni filtri.....	12
3. FIR i IIR filtri	13
3.1. IIR filtri.....	14
3.2. FIR filtri.....	15
3.3. Usporedba FIR i IIR filtra	15
4. Osrednjavajući filter	16
4.1.Osrednjavajući filter s pomičnim vremenskim prozorom	17
4.2.Osrednjavajući filter s eksponencijalno opadajućim težinskim koeficijentom.....	18
5.Metode uklanjanja smetnji sa signala	21
6. Sinteza filtera primjenom vremenskih prozora	22
7. Toplinska obrada	25
7.1. Kaljivost čelika	26
7.1.1. Zakaljivost čelika.....	26

7.1.2. Prokaljivost čelika	27
8. Prikupljanje i procjena podataka u eksperimentu kaljenja	29
8.1. Mjerni sustav	30
8.2. Obrada sirovih podataka.....	31
8.3. Proračun funkcija	31
8.4. Rezultati ispitivanja	32
8.5. Filtriranje rezultata	40
8.5.1. Odabir metode filtriranja	40
8.5.2. Filtriranje sirovih podataka.....	44
9. Zaključak	52
Literatura	53
Prilog	54

Popis slika

Slika 2.1. Podjela signala	2
Slika 2.2. Analogni signal prije i poslije mjerenja	4
Slika 2.3. Rezolucija AD pretvornika	5
Slika 2.4. Ovisnost izgleda snimljenog signala o f_{sr}	7
Slika 2.5. Odziv idealnog i realnog filtera	8
Slika 2.6. Općeniti sistem digitalne obrade signala	9
Slika 2.7. Primjer digitalne integracije	10
Slika 2.8. Idealni frekvencijski odziv filtera	11
Slika 4.1. Kretanje n niza podataka	13
Slika 4.2. Eksponencijalni rast težina	20
Slika 6.1. Frekvencijski odziv idealnog niskopropusnog filtera	22
Slika 6.2. Impulsni odziv idealnog niskopropusnog filtera	22
Slika 6.3. Oblik signala nakon modifikacije	23
Slika 6.4. Frekvencijski odziv modificiranog signala	23
Slika 6.5. Blackmanov vremenski prozor	24
Slika 6.6. Rezultat množenja Blackmanovog vremenskog prozora sa funkcijom sinc	24
Slika 6.7. Rezultat impulsnog odziva filtera	24
Slika 7.1. Dijagramski prikaz toplinske obrade	26

Slika 7.2. Burnsov dijagram maksimalne postizive tvrdoće zakaljenih čelika u ovisnosti udjelu ugljika	27
Slika 7.3. Utjecaj dimenzija čeličnog predmeta na njegovu prokaljenost	28
Slika 8.1. Mjerni sustav	30
Slika 8.2. Temperatura – vrijeme (ulje)	32
Slika 8.3. Temperatura – vrijeme (polimer).....	33
Slika 8.4. Razlika temperatura – vrijeme (ulje)	33
Slika 8.5. Razlika temperatura – vrijeme (polimer)	34
Slika 8.6. Gustoća toplinskog toka – vrijeme (ulje)	34
Slika 8.7. Gustoća toplinskog toka – vrijeme (polimer)	35
Slika 8.8. Gustoća toplinskog toka – temperatura površine (ulje)	35
Slika 8.9. Gustoća toplinskog toka – temperatura površine (polimer)	36
Slika 8.10. Integral gustoće toplinskog toka – vrijeme (ulje)	36
Slika 8.11. Integral gustoće toplinskog toka – vrijeme (polimer)	37
Slika 8.12. Brzina hlađenja – vrijeme (ulje)	37
Slika 8.13. Brzina hlađenja – vrijeme (polimer)	38
Slika 8.14. Brzina hlađenja – temperatura površine (ulje)	38
Slika 8.15. Brzina hlađenja – temperatura površine (polimer)	39
Slika 8.16. Odabir metode filtriranja	41
Slika 8.17. Prva skupina metoda filtriranja	41
Slika 8.18. Druga skupina metoda filtriranja	42
Slika 8.19. Treća skupina metoda filtriranja	42
Slika 8.20. Četvrta skupina metoda filtriranja	43
Slika 8.21. Najbolje metode filtriranja	43
Slika 8.22. Temperatura – vrijeme (ulje, filtrirano)	44
Slika 8.23. Temperatura – vrijeme (polimer, filtrirano)	45
Slika 8.24. Razlika temperatura – vrijeme (ulje, filtrirano)	45
Slika 8.25. Razlika temperatura – vrijeme (polimer, filtrirano)	46
Slika 8.26. Gustoća toplinskog toka – vrijeme (ulje, filtrirano)	46
Slika 8.27. Gustoća toplinskog toka – vrijeme (polimer, filtrirano)	47
Slika 8.28. Gustoća toplinskog toka – temperatura površine (ulje, filtrirano)	47
Slika 8.29. Gustoća toplinskog toka – temperatura površine (polimer, filtrirano)	48
Slika 8.30. Integral gustoće toplinskog toka – vrijeme (ulje, filtrirano)	48

Slika 8.31. Gustoća toplinskog toka – temperatura površine (polimer, filtrirano)	49
Slika 8.32. Brzina hlađenja – vrijeme (ulje, filtrirano).....	49
Slika 8.33. Brzina hlađenja – vrijeme (polimer, filtrirano)	50
Slika 8.34. Brzina hlađenja – temperatura površine (filtrirano)	50
Slika 8.35. Brzina hlađenja – temperatura površine (filtrirano)	51

Popis tablica

Tablica 3.1. Usporedba IIR i FIR filtera	15
--	----

Popis oznaka

Oznaka	Jedinica	Opis
Δt	s	vremenski interval
t	s	vrijeme
q	-	kvant
B	-	broj bitova
A	-	raspon signala
f	Hz	frekvencija
t	s	vrijeme
$A_i(f)$	Hz	amplituda frekvencije prije filtriranja
$A_o(f)$	Hz	amplitude frekvencije poslije filtriranja
N_x	-	broj koeficijenata naprijed
N_y	-	broj koeficijenata nazad
h	-	koeficijent filtra
s	-	standardna devijacija
ϑ_{TO}	°C	temperature toplinske obrade
T_C	°C	temperatura u centru
T_i	°C	temperatura ispod površine
T_s	°C	temperatura površine
v	m/s	brzina
q	W/m ²	gustoća toplinskog toka
λ	W/(mK)	toplinska vodljivost
r	m	radijalna udaljenost
dT/dt	°C/s	brzina hlađenja



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum: 26-02-2015	Prilog
Klasa: 602-04/15-G/3	
Ur.broj: 15-1703-15-131	

ZAVRŠNI ZADATAK

Student: **Hrvoje Pinculić**

Mat. br.: 0035180197

Naslov rada na
hrvatskom jeziku:

**Obrada eksperimentalnih podataka procesa zakaljivanja primjenom
osrednjavajućih i interpolacijskih digitalnih filtara**

Naslov rada na
engleskom jeziku:

**Quenching process experimental data processing by means of averaging
and interpolating digital filters**

Opis zadatka:


Prilikom vrednovanja postupka zakaljivanja informacija o gradijentu temperature predstavlja ključan podatak o njegovoj kvaliteti. Kako bi se iz eksperimentalnih podataka, koji često mogu biti izrazito zašumljeni, kvalitetno procijenio iznos temperaturnog gradijenta potrebno je primijeniti postupke digitalne obrade signala primjenom digitalnih filtara za izgladivanje signala (engl. signal smoothing). Pritom se u praksi često koriste takozvani osrednjavajući i interpolacijski filtri, koji na pred-definiranom vremenskom „prozoru“ (intervalu) računaju otežanu aritmetičku sredinu mjernih točaka, odnosno lokalno aproksimiraju podatke polinomskom krivuljom. U radu je potrebno napraviti sljedeće:

1. Opisati i usporediti strukture digitalnih filtara za izgladivanje signala zasnovane na osrednjavanju odnosno lokalnoj aproksimaciji interpolacijskim polinomom, s posebnim naglaskom na utjecaj izbora vremenskog prozora, te težinskih faktora kod osrednjavajućih filtara, odnosno reda polinomske aproksimacije kod interpolacijskih filtara.
2. U programskom paketu Matlab/Simulink razviti odgovarajuće programske rutine za obradu i prikaz podataka koristeći postojeće biblioteke funkcija za obradu signala primjenom osrednjavajućih i interpolacijskih filtara. Ove rutine također trebaju uključivati pripremu konačnih rezultata za grafički prikaz primjenom odgovarajućih funkcija za sortiranje podataka.
3. Razvijene programske rutine za obradu i prikaz podataka treba primijeniti za obradu eksperimentalnih podataka postupka zakaljivanja, te na temelju dobivenih rezultata vrednovati performanse pojedinih filtara i dati preporuke za njihovo korištenje.

Zadatak zadan:

25. studenog 2014.

Zadatak zadao:


Prof. dr. sc. Davor Zorc

Rok predaje rada:

1. rok: 26. veljače 2015.


2. rok: 17. rujna 2015.

Predviđeni datumi obrane:

1. rok: 2., 3., i 4. ožujka 2015.

2. rok: 21., 22., i 23. rujna 2015.

Predsjednik Povjerenstva:


Prof. dr. sc. Zoran Kunica

1. Uvod

Prilikom obrade podataka procesa zakaljivanja informacija o gradijentu temperature predstavlja ključan podatak o njegovoj kvaliteti. Međutim, eksperimentalni podaci često mogu biti izrazito zašumljeni (npr. kvantizacijski šum zbog ograničene rezolucije senzora), što predstavlja problem za kvalitetnu procjenu iznosa temperaturnog gradijenta.

Stoga je potrebno primijeniti postupke digitalne obrade signala primjenom digitalnih filtera za izgladivanje signala (eng. signal smoothing), pri čemu se u praksi često koriste takozvani osrednjavajući filtri.

U ovom završnom radu se opisuju i uspoređuju digitalni filtri za izgladivanje signala zasnovane na osrednjavanju, s posebnim naglaskom na utjecaj izbora vremenskog prozora, te težinskih faktora kod osrednjavanja filtera. Razvoj i implementacija filtera i popratnih programskih rutina u programskom paketu MatLAB/Simulink, uključivo s pripremom konačnih rezultata za grafički prikaz koji će poslužiti za interpretaciju rezultata zakaljivanja.

Rad je organiziran kako slijedi. U poglavlju 2. objašnjeni su signali, njihove podjele, neke od glavnih karakteristika signala (rezolucija, kvantizacija signala), te je dan općeniti uvod u digitalnu obradu signala i filtriranje signala, te je prikazan i primjer jedne takve obrade signala. Navedena su i objašnjenja digitalnih filtera, te njihova podjela na realne i idealne, njihove razlike i sličnosti.

U 3. poglavlju su obrađeni FIR i IIR filtri, njihove karakteristike, razlike i sličnosti, te je dana tablica sa kraćim usporedbama između ta dva tipa filtra.

Nadalje, u poglavlju 4. opisani su jedni od najčešće korištenih niskopropusnih FIR filtera, koji su najjednostavniji i najoptimalniji za smanjenje šumova, a to su osrednjavajući filtri. Dan je detaljan pregled ovih filtera, te je opisan osrednjavajući filter s pomičnim vremenskim prozorom uz poseban naglasak na izbor težinskih faktora kod osrednjavajućih filtera.

U poglavlju 5. su ukratko opisani izvori smetnji u korisnim signalima, njihova podjela i razlozi pojavljivanja, te osnovni postupci njihovog uklanjanja.

U poglavlju 6. opisana je sinteza filtera primjenom vremenskih prozora. Objašnjeni je razlozi korištenja vremenskih prozora, te problemi kod takvih vremenskih prozora, te rješenje za takve probleme.

Toplinska obrada je opisana u poglavlju 7. Detaljan opis i vrste toplinske obrade, kao i dijagramski prikaz takve obrade, razlike između zakaljivosti i prokaljivosti čelika opisane su u ovom poglavlju.

U poglavlju 8. opisan je postupak prikupljanja i procjene podataka u eksperimentu zakaljivanja. Opisan je mjerni sustav koji se koristio u ovom eksperimentu, te obrada podataka koje smo prikupili ovim eksperimentom. Navedene su i prikazane neke funkcije koje su zanimljive prikazati, te problemi pri prikazu tih funkcija. Izabrana je najbolja metoda kojom se filtriraju te funkcije, ona nam omogućuje kvalitetniji prikaz samih rezultata.

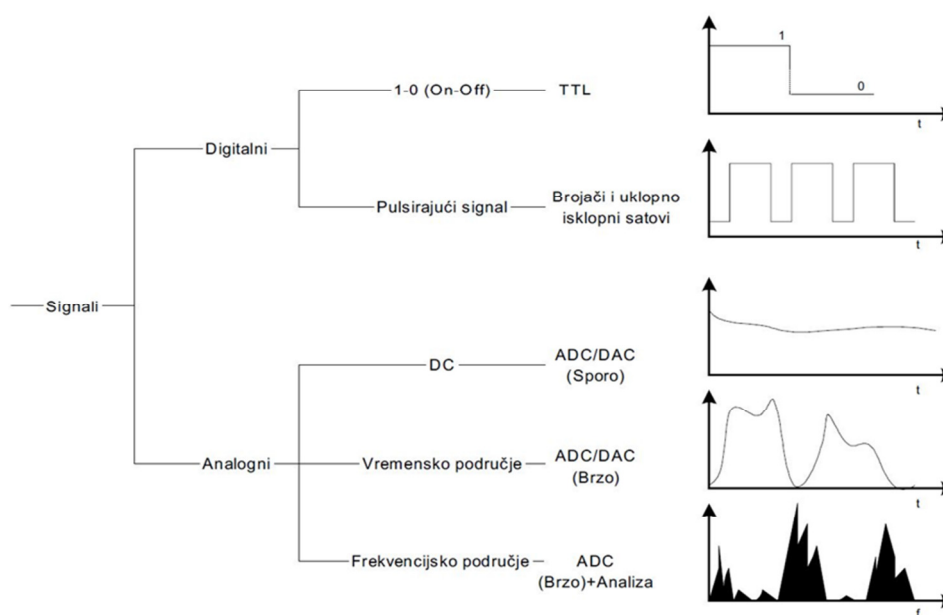
U prilogu je dan MatLAB kod za program „Evaluacija_mjernih_podatka_zakaljivanja“ pomoću kojeg možemo simulirati sve navedene funkcije u ovom radu.

2. Signali

Signal je materijalni ili energetska nosilac informacija. Obično je to varijacija neke fizikalne veličine koju je moguće izmjeriti, manipulirati, pohraniti, prenijeti ili obraditi nekim fizikalnim procesom. [10]

2.1 Podjela signala

Ako se signal želi svrstati prema načinu na koji daje određenu informaciju tada ga je moguće podijeliti na digitalni i analogni signal. Digitalni ili binarni signal ima samo dva moguća nivoa: visoko („on“) stanje ili nisko („off“) stanje. Analogni sadrži informaciju o kontinuiranoj promjeni signala s vremenom. Digitalni se signali dijele na dvije skupine, a to su „on-off“ signali i pulsirajući signali. Analogni se dijele na tri skupine: gotovo nepromjenljivi u vremenu (istosmjerni ili DC signali), signali u vremenskoj domeni (AC ili izmjenični signali) i signali u frekvencijskoj domeni. Podjela je prikazana na slici 2.1.



Slika 2.1. Podjela signala

Svaki tip signala prenosi točno određen tip informacija koja odgovara parametrima kao što su: stanje, nivo (amplituda), oblik i frekvencijski sadržaj.

2.1.1 Digitalni i analogni signali

Prvi tip digitalnog signala je „on-off“ signal. On daje informaciju o digitalnom stanju signala pa je stoga instrument potreban za njegovo mjerenje jednostavani detektor digitalnog stanja. Izlaz tranzistor-tranzistor logične sklopke (TTL sklopka) je primjer on-off signala.

Drugi tip digitalnog signala je pulsirajući signal. Informacija koju on pruža sastoji se od broja prijelaza iz jednog stanja u drugo, učestalosti prijelaza iz jednog stanja u drugo (frekvencija promjene stanja) i vremenu između jednog i drugog stanja. Primjer takvog signala je optički enkoder koji je spojen na osovinu motora.

Analogni DC je statički ili sporo promjenljivi analogni signal. Glavna karakteristika DC signala jest informacija o amplitudi ili nivou tog signala u određenim vremenskim trenucima. Zbog toga što se DC signal malo mijenja s vremenom, bitnija je točnost izmjerene amplitude signala nego brzina kojom se uzimaju uzorci tog signala. Sklop koji dovodi taj signal u računalo radi na principu analogno-digitalne prevorbe (ADC) pomoću koje se analogni električni signal pretvara u digitalne vrijednosti kako bi ga računalo moglo interpretirati. Primjer DC signala su temperatura i napon baterije.


Analogni AC signali razlikuju se od ostalih signala po tome što daju ne samo informaciju o amplitudi, nego i o tome kako se mijenja oblik signala s vremenom. Kada se mjeri oblik signala koji se još često naziva i valni oblik, od važnosti su i karakteristike koje proizlaze iz oblika, kao naprimjer nul točke signala itd. Za mjerenje AC signala potrebno je precizno odrediti trenutke mjerenja pojedinih točaka signala. Također frekvencija mjerenja točaka mora biti točno određena kako bi se signal mogao adekvatno rekonstruirati. Mjerenje valja započeti u točno određenom trenutku kako bi se snimio koristan dio signala. Slijedi da sustav za mjerenje AC signala mora imati AD pretvornik, sat koji određuje kada se događa pretvorba i okidač koji započinje mjerenje u određenom trenutku kada je zadovoljen neki uvjet.

Analogni signali u frekvencijskom području slični su analognim AC signalima u vremenskom području jer također daju informaciju o tome kako se signal mijenja s vremenom. No, međutim, informacija koja se dobiva iz signala u frekvencijskoj domeni bazira se na frekvencijskom sadržaju signala, za razliku od oblika i ostalih karakteristika koje se dobivaju kada se signal nalazi u vremenskom području. [5]

2.2 Uzimanje uzoraka signala

Ako želimo izvršiti digitalnu obradu signala tada je potrebno prvo analogni signal pretvoriti u digitalni oblik. U praksi se za to koriste analogno-digitalni pretvornici (ADC).

Neka je $x(t)$ analogni signal čiji se uzorci uzimaju svakih Δt sekundi. Vremenski interval Δt naziva se interval ili period uzimanja uzoraka. Vremenski interval $1/\Delta t$ naziva se frekvencija uzimanja uzoraka. Svaka diskretna vrijednost valnog oblika $x(t)$ u trenucima $t = 0, \Delta t, 2\Delta t, 3\Delta t, \dots$ naziva se uzorak signala $x(t)$. Dakle $x(0), x(\Delta t), x(2\Delta t) \dots$ uzorci su signala.



Slika 2.2. Analogni signal prije i poslije mjerenja

Na slici 2.2. prikazan je analogni signal i verzija tog signala sa uzorcima. Period uzimanja iznosi Δt . Valja primijetiti da su uzorci definirani u diskretnim vremenskim trenucima. Ako postoji n uzoraka signala $x(t)$, tada se $x(t)$ može prikazati kao

$$x = \{x[0], x[1], x[2], x[3], \dots, x[n-1]\} \quad (1)$$


To se još naziva digitalni prikaz analognog signala $x(t)$ ili prikaz pomoću uzoraka. Izraz (1) je indeksiran pomoću cijelih brojeva i stoga ne sadržava nikakvu informaciju o frekvenciji uzimanja uzoraka. Pa iz toga možemo zaključiti da su poznate samo pojedine vrijednosti uzoraka i njihov broj te nije moguće saznati koja je bila frekvencija uzimanja uzoraka. [5]

2.2.1 Rezolucija

Računalo sprema informaciju u digitalnom obliku s konačnim brojem bitova. Svaki uzorak analognog signala stoga treba pretvoriti u konačan broj bitova prije nego što može ići na daljnju obradu pomoću računala. Ta pretvorba se postiže analogno-digitalnim pretvornikom (ADC). Važan parametar ADC-a je njegova rezolucija, odnosno broj bitova koji koristi za prikazivanje analognog signala. Budući da je broj bitova konačan, a kontinuirani analogni signal može imati beskonačno mnogo vrijednosti, tada je potrebno određeni niz analognog signala mapirati na određenu kombinaciju bitova.

Što je veća rezolucija ADC-a to je i veći broj dijelova na koje je moguće mapirati pojedine vrijednosti signala, a samim time detektirati manje promjene mjernog signala.

Na slici 2.3. je prikazan neki analogni signal i rezolucija analogno-digitalnog pretvornika. [5]



Slika 2.3. Rezolucija AD pretvornika

2.2.2 Kvantizacija

Kvantizacija predstavlja proces diskretizacije po amplitudi. To je proces u kojem se signal mijenja na način da se vrijednosti signala „zaokružuju“ na točno određene (diskretne) vrijednosti (razine kvantizacije). To znači da će umjesto grupe bliskih vrijednosti amplituda uvijek biti određena jedna unaprijed izabrana amplituda. Na ovaj način skup svih amplituda svodi se na konačan skup. Osnovna karakteristika procesa kvantizacije je pojava greške, odnosno šuma kvantizacije u signalu. Utjecaj šuma kvantizacije ovisi o rezoluciji, to jest o veličini koraka kvantizacije.

Razlika između dvije susjedne razine kvantizacije naziva se korakom kvantizacije ili kvantom. Veza kvanta i broja bitova potrebnih za kvantizaciju dana je izrazom:

$$q = \frac{A}{2^B - 1} \quad (2)$$

Gdje je q kvant, B broj bitova, a A raspon signala. [6]


2.2.3 Nyquistov teorem

Teorem uzrokovanja ili Nyquist-Shannonov teorem govori je kako se analogni kontinuirani signal može pretvoriti u slijed vremenskih diskretnih impulsa (uzoraka) i obrnuto, tako da nema nikakvog gubitka informacija ako je ostvareno sljedeće:

Frekvencija f_{sr} („sampling rate“) kojom se uzimaju uzorci mora biti najmanje dva puta viša od najviše frekvencije f_m koja se može pojaviti u analognom signalu koji se uzrokuje, to jest: $f_{sr} \geq 2f_m$.

Drugim riječima: u analognom kontinuiranom signalu ne smije biti viših frekvencija nego što je polovica frekvencije uzrokovanja f_{sr} , kako bi pretvorba iz kontinuiranog signala u niz diskretnih impulsa (vrijedi i obrnuto: pretvorba iz niza diskretnih impulsa u kontinuirani signal) bila moguća bez ikakvog gubitka informacija.

Za primjer ćemo uzeti signale prikazane na slici 2.4. Na prvom signalu uzimani su uzorci dovoljno brzo i njegov digitalni prikaz je zadovoljavajući. Kod drugog signala frekvencija uzimanja uzoraka nije bila dovoljno brza i zbog toga postoji izmjereni signal koji izgleda tako da ima drugačiju frekvenciju od stvarnog signala. Krivi prikaz izmjereno signal naziva se „alias“.




Slika 2.4. Ovisnost izgleda snimljenog signala o f_{sr}

2.2.4 Analogni filtri

Frekvencija uzimanja uzoraka mora biti barem dva puta veća od maksimalne frekvencije analognog signala koji se mjeri. Problem je to osigurati u praktičnoj primjeni. Čak i ako se zna koja će biti maksimalna frekvencija signala koji se želi mjeriti, uvijek se mogu javiti smetnje od okolnih uređaja koje sadrže frekvencije koje su više od Nyquistove. One se javljaju kao „alias“ i tada dobijemo iskrivljenu sliku signala.

Kako bi se to spriječilo koriste se niskopropusni analogni filteri (propuštaju niže, a prigušuju više frekvencije), koji se spajaju u mjerni krug prije uzimanja uzoraka i prije AD pretvorbe. Ti filteri se još nazivaju i „antialias“ filteri jer im je glavna zadaća izbjegavanje pojave aliasa signala koji kao posljedicu ima netočnu digitalnu obradu signala. Idealna karakteristika „antialias“ filtera je prikazana na slici 2.5a. Prema toj karakteristici oni propuštaju sve frekvencije ispod f_1 i to s prigušenjem jednakim nula, dok one iznad f_1 ne propušta, nego se prigušuju. Drugim riječima amplituda izlaznog signala iz filtera je jednaka amplitudi ulaznog signala ili je jednaka nuli u drugom slučaju.



Slika 2.5. Odziv idealnog i realnog filtera

Karakteristike realnih filtera nisu takve, već izgledaju kao na slici 2.5b. U praksi nije moguće postići naglu granicu između područja propuštanja i područja nepropuštanja signala. Propusno područje je sve do f_1 , a područje prigušenja sve iznad f_2 .

Područje između f_1 i f_2 naziva se prijelazno područje i frekvencije koje spadaju u njega se propuštaju, ali i postupno prigušuju. Iako se želi propustiti frekvencije manje od f_1 , frekvencije u prijelaznom području ipak mogu izazvati „alias“ efekt. Iz tog razloga kada se odabere frekvencija uzimanja uzoraka u praksi, potrebno ju je odabrati da bude dva puta veća od najveće frekvencije u prijelaznom području.


2.3 Digitalna obrada signala i filtriranje

Digitalna obrada signale (eng: Digital Signal Processing) odnosi se na sve što se može raditi signalom, koristeći računalni kod ili DSP čip. Filter je sklop koji propušta (ne prigušuje) one frekvencijske komponente koje se nalaze unutar njegovog propusnog opsega frekvencija dok prigušuje sve ostale frekvencijske komponente.

Ako u signalu postoje šumovi, tada filtriranje signala smanjuje amplitudnu frekvencije šuma i time poboljšava kvalitetu signala. Na primjer, šum se može pojaviti prilikom snimanja glazbe zbog vjetra. Filtriranje sinusoidalne komponente signala koja se pojavljuje kod frekvencija koje ne mogu biti proizvedene samo od strane glazbe daje kao rezultat glazbu s malo šumova uzrokovanog od strane vjetra. Neka signal nije izobličen zbog šuma, nego zbog ostalih frekvencija koje nam nisu od interesa. [3]

2.3.1 Primjeri digitalne obrade signala

Digitalna obrada signala uključuje digitalno filtriranje signala kao i digitalnu integraciju i digitalnu korelaciju signala. Koncept je vrlo jednostavan. Signal se podjeli po vremenu pa se upisuju veličine signala u periodičnim intervalima u računalu. Svaka analogna vrijednost tog signala pretvara se u binarni broj. Uzorkovanje i pretvoba se obavlja analogno-digitalnim pretvaračem. Sada računalni kod može raditi na signalu. Računalni kod računa krajnju vrijednost koja je pretvorena iz binarnog u analogni broj i ona je konstantna dok se nova vrijednost ne izračuna i zamjeni je. Općenita digitalna obrada signala prikazana je na slici 2.6.



Slika 2.6. Općeniti sistem digitalne obrade signala

Ako je analogno-digitalni pretvarač uzimao uzorak signala svakih „ T “ sekundi, ako tu vrijednost množimo s konstantom i pošaljemo digitalno analognom pretvaraču, dobit ćemo digitalno pojačalo. Pojačanje pojačala jednako je kodiranoj vrijednosti konstante. Donja jednadžba opisuje digitalno pojačalo, gdje je „ x “ trenutna vrijednost analogno-digitalnog pretvarača, a „ y “ je odgovarajuća vrijednost izlaza iz računala do digitalno-analognog pretvarača.

$$y = ax \quad (3)$$

Ako je vrijednost uzorka ulaznog signala pomnožena sa „T“, izračunali smo aproksimaciju površine ispod signala između uzorka signala, sve dok se signal ne mijenja previše između uzoraka. Ako je vrijednost dodana na prethodnom ulaznom uzorku pomnožena s „T“, dobit ćemo aproksimaciju površine ispod signala kroz dva vremenska uzorka. To možemo ponavljati beskonačno puta (slika 2.7.). Ta površina ispod signala ili funkcije je integral. Tako smo proveli vrlo jednostavnu digitalnu integraciju koristeći postojeći uzorak ulaza pomnožen s „T“ te dodali taj rezultat na prošli izlaz. Ovaj proces je opisan sljedećim jednažbama nakon dva ulazna uzorka („1“ indeks sugerira na prijašnju ulaznu ili izlaznu vrijednost)


$$y_{-1} = T \quad (4)$$

$$y = y_{-1} + Tx \quad (5)$$

Jednažbe (4) i (5) su jednažbe digitalne integracije nakon 1 uzorka, odnosno 2 uzoraka izlaza. Koristeći petlje, kao na primjer „while“ ili „for“, te jednažbe se mogu ponavljati u beskonačnost.

Ako je trenutna ulazna vrijednost uzorka pomnožena s jednom polovinom i dodana na polovinu prošle ulazne vrijednosti uzorka, trenutna promjena u ulaznom signalu je smanjena, sve dok se signal mijenja sporo izlaz je vrlo blizu ulazu zbog toga što je to jednostavan zbroj dvije polovine vrijednosti. Tako računalo radi vrlo jednostavno nisko propusno filtriranje ulaznog signala. Taj proces je predstavljen jednažbom (6)

$$y = 0,5x + 0,5x_{-1} \quad (6)$$



Slika 2.7. Primjer digitalne integracije

2.4 Digitalni filtri

Mnogo puta u svakodnevnom životu mjerimo količine nekih varijabli. Neki primjeri su tlak, jačina potresa, sjaj zvijezde, populacija grada ... Sva ta mjerenja ovise o vremenu i odnosimo se prema njima kao da su funkcija vremena - $x(t)$ u matematičkom zapisu.

Najčešće se te varijable mogu gledati kao da su mjerena kontinuirano (analogni signali). Iz tehničkih razloga, umjesto da snimimo cijeli signal $x(t)$, često tek snimimo u jednakim razmacima uzorak x_n funkcije $x(t)$. Osim toga, kada smo uzimali uzorke nismo uzimali s beskonačnom preciznošću, već su zaokruženi na nekoliko znamenaka. Taj proces se naziva kvantizacija signala. Ti kvantizirani signali mogući su za obradu. Mi radimo obradu da bismo razumjeli te signale, a digitalni filter je glavni alat za to. [5]

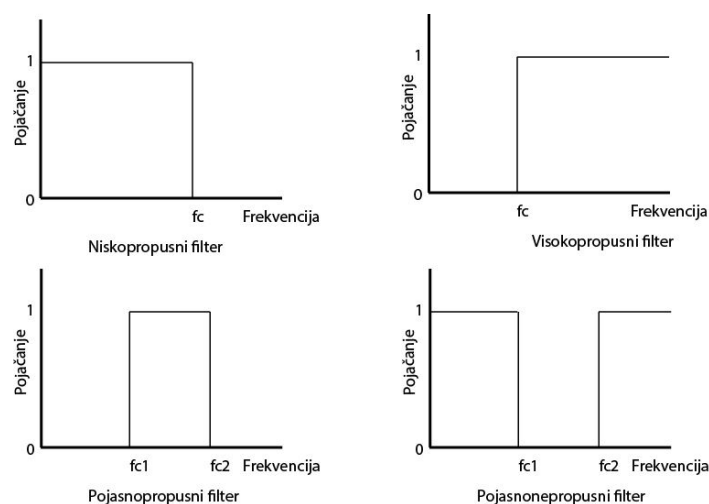
2.4.1 Idealni filtri

Filtriranje je proces kojim se mijenja frekvencijski sadržaj signala i potpuno se uklanjaju neželjene frekvencije iz signala.

Ovisno o frekvencijskom pojasu koji ili propušta ili prigušuje signal, filteri se mogu podijeliti na:

- Niskopropusni filteri - propuštaju niske, a prigušuju visoke frekvencije
- Visokopropusni filteri – propuštaju visoke, a prigušuju niske frekvencije
- Pojasnopropusni filteri – propuštaju određeni pojas frekvencija
- Pojasnonepropusni filteri – prigušuju određeni pojas frekvencija

Idealni frekvencijski odziv prikazan je na slici 2.8.



Slika 2.8. Idealni frekvencijski odziv filtera

Iz slike vidimo da niskopropusni filter propušta frekvencije ispod f_c , dok visokopropusni filter propušta frekvencije iznad f_c . Pojasnopropusni propušta sve frekvencije između f_{c1} i f_{c2} . Frekvencije f_c se nazivaju granične frekvencije filtera i pri dizajnu filtera ih je potrebno odrediti. Područje filtera koje propušta frekvencije naziva se propusni pojas filtera, a područje koje ne propušta frekvencije, već ih prigušuje naziva se nepropusni pojas. [13]

2.4.2 Realni filtri

U stvarnosti stvari nisu tako idealne. Granična frekvencija nikad nije oštra već uvijek postoji prijelazno područje između propusnog i nepropusnog pojasa. U tom prijelaznom području se pojačanje filtera postupno mijenja od jedinice do nule. Prigušenje signala u nepropusnom pojasu u stvarnosti ne može biti beskonačno, već ima neku minimalnu vrijednost. Prigušenje se mjeri u decibelima pomoću formule:

$$dB = 20 \log_{10} \left(\frac{A_0(f)}{A_i(f)} \right) \quad (7)$$

$A_i(f)$ i $A_0(f)$ su amplitude određene frekvencije prije i poslije filtriranja.

3. FIR i IIR filteri

Filteri se mogu razvrstati u nekoliko različitih skupina, ovisno o tome koji se kriteriji koriste za klasifikaciju. Dvije glavne vrste digitalnih filtera su digitalni filter s konačnim impulsnim odzivom (FIR filter) i digitalni filter s beskonačnim impulsnim odzivom (IIR filter).

FIR i IIR filteri imaju neke prednosti i nedostatke koje treba razmotriti prilikom dizajniranja filtra. Osim toga potrebno je uzeti u obzir sve temeljne karakteristike signala koji trebamo filtrirati. U većini slučajeva jedna karakteristika je važna koja određuje koji filter ćemo koristiti, a to je da li je potrebno da filter ima linearnu faznu karakteristiku ili ne.

Signal razgovora, na primjer, može se obraditi u sustavima s nelinearnom faznom karakteristikom. Karakteristika takvog signala nema toliku važnost i kao takva može se zanemariti što za posljedicu ima korištenje većeg raspona sustava za obradu signala.

Također, postoje i signali kod kojih je karakteristika od veće važnosti. Tipičan primjer takvih signala su oni dobiveni iz raznih senzora u industriji. Stoga je potrebno da filter ima linearnu faznu karakteristiku da bi izbjegli gubitak važnih informacija.

Kada želimo filtrirati signal analiziramo ga na sljedeći način; lagano je odlučiti koji tip digitalnog filtra je najbolje koristiti. Prema tome ako je fazna karakteristika od važnosti, potrebno je koristiti FIR filtre jer oni imaju linearnu faznu karakteristiku. Takvi filteri su puno složeniji. Također, kada je bitan samo frekvencijski odziv, poželjno je koristiti IIR filtre koji su daleko manje složeni i mogu se lakše razumjeti. [12]

Osnovne karakteristike FIR filtra su:

- stabilnost
- linearna fazna karakteristika
- visoki red filtera

Osnovne karakteristike IIR filtra su:

- digitalni filter ima potencijal da postane nestabilan
- nelinearna fazna karakteristika
- niski red filtra

3.1 IIR filtri

IIR filtri su digitalni filtri čiji se izlazni podaci računaju zbrajanjem s prijašnjim vrijednostima, pomnoženih s nekim težinskim faktorom, s trenutnim i prijašnjim ulaznim vrijednostima također pomnoženim s nekim težinskim faktorom. Ako se ulazne vrijednosti označe sa x , a izlazne sa y tada možemo napisati jednadžbu razlike IIR filtra koja glasi:

$$a_0 y[i] = -a_1 y[i-1] - a_2 y[i-2] + \dots - a_{N_y-1} y[i - (N_y - 1)] + b_0 x[i] + b_1 x[i-1] + b_2 x[i-2] + \dots + b_{N_x-1} x[i - (N_x - 1)] \quad (8)$$

Nakon sređivanja slijedi:

$$y[i] = \frac{1}{a_0} \left(-\sum_{j=1}^{N_y-1} a_j y[i-j] + \sum_{k=0}^{N_x-1} b_k x[i-k] \right) \quad (9)$$

gdje je N_x broj koeficijenata naprijed (b_k), a N_y je broj koeficijenata nazad (a_j). Trenutna izlazna vrijednost i je suma trenutnih i prijašnjih vrijednosti $x[i]$ i $x[i-k]$ (za $k \neq 0$), pomnoženih s težinskim faktorima i prijašnjih izlaznih vrijednosti $y[i-j]$ (za $j \neq 0$) također pomnoženih s težinskim faktorima. Obično je N_x jednak N_y , a red filtra je jedank $N_x - 1$. Niži red filtera smanjuje broj aritmetičkih operacija i samim time smanjuje i greške koje nastaju računanjem. Problem sa filtrima većeg reda je taj da vrlo brzo nastaju pogreške u računanju koje se odnose na preciznost rezultata. [6]

Neki od najčešćih IIR filtra su:

- Butterworth filter
- Eliptični filter
- Chebyshevi filter

3.2 FIR filter

Izlaz kod FIR filtra ovisi samo o trenutnim i prošlim ulazima. Za razliku od IIR filtra kod kojih izlaz ovisi o prošlim izlazima i o trenutnim i prošlim ulazima. Zbog toga njegov impulsni odziv pada prema nuli u nekom konačnom vremenskom periodu. Izlaz filtra se može opisati jednadžbom:

$$y[i] = h_0x[i] + h_1x[i - 1] + \dots + h_nx[i - n] \quad (10)$$

Nakon sređivanja dobijemo:

$$y[i] = \sum_{k=0}^{n-1} h_k x[i - k] \quad (11)$$

gdje je x vrijednosti na ulazu, y su vrijednosti na izlazu, a h koeficijenti filtra.

FIR filtri postižu linearni prikaz faznog odziva i stoga propuštaju signal bez iskrivljenja faze. Uvijek su stabilni, a prilikom dizajniranja nije potrebno voditi računa o stabilnosti, jednostavniji su i lakše ih je koristiti od IIR filtra [6]

3.3 Usporedba FIR i IIR filtra

S obzirom na specifikacije, trebamo odlučiti da li željeni filter treba biti IIR ili FIR. Sljedeća tablica prikazuje različite čimbenike koje bi nam mogle pomoći u donošenju te odluke (tablica 3.1.).

	IIR filter	FIR filter
Faza	Teško za kontrolirati, ne treba određena tehnika	Linearna faza uvijek moguća
Stabilnost	Može biti nestabilno	Uvijek stabilno
Red	Manji	Veći
Povijest	Derivirano iz analognog filtra	Nema analogne povijesti

Tablica 3.1. Usporedba IIR i FIR filtera [6]

4 Osrednjavajući filter

Jedan od klasičnih primjera niskopropusnih FIR filtra je osrednjavajući filter. Osrednjavajući filter je jedan od jednostavnijih filtra i najoptimalniji za smanjenje slučajnih šumova i jedan od najbržih filtra. Oni imaju slabu mogućnost za odvajanje jednog područja propuštanja frekvencija od drugog.

Osrednjavajući filter računa prosjek ulaznih uzoraka i kao izlaz dobivamo jedan izlazni uzorak. To osrednjavanje skida visoku frekvencijsku komponentu koja je prisutna u signalu.

Jednostavni prosjek može se iskoristiti za smanjenje šuma. Pretpostavimo da imamo n mjera varijable x . Standardna devijacija tih izmjerenih varijabla može se odrediti pomoću formule:

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (12)$$

gdje je \bar{x} aritmetička sredina od n izmjera izračunata kao:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (13)$$

Veličina varijable s ovisna je o izmjerama, x_i , i također ovisna o broju mjerenja n . Iz gornje jednadžbe možemo zaključiti da čim je veći broj mjerenja (n) to je manja vrijednost standardne devijacije (s). Drugim riječima, ako je određeno mjerenje ima puno šuma, možemo uzeti veći broj očitavanja varijable i iskoristiti prosjek kako bismo dobili bolju procjenu njene stvarne vrijednosti (pod uvjetom da nema sustavne pogreške prilikom mjerenja). To je zapravo standardna procedura u eksperimentalnom radu, gdje se broj očitavanja uzima u trenutku uzimanja uzoraka te se prosjek tih očitavanja koriste kao mjera.

Iako je jednostavno izračunati prosjek pomoću gornje formule, to je ne učinkovito, kako u pogledu spremanja podatka tako i zahtjevima računala. S obzirom da su memorije i brzi mikroprocesori jeftini, to ne predstavlja problem. Međutim, opterećenje procesora može biti od velike važnosti kada uzmemo u obzir stotine, možda i tisuće mjerenja koja su napravljena za najjednostavniji proces. Stoga trebamo gledati na učinkovitije načine računanja prosjeka. [9]

4.1 Osrednjavajući filter s pomičnim vremenskim prozorom

Poboljšanje računalne učinkovitosti može se postići ako računamo prosjek rekurzivno. Rekurzivno rješenje je ono koje ovisi o prethodno izračunatoj vrijednosti.

Pretpostavimo da za svaki trenutak k , prosjek posljednjih n uzoraka podataka x_i određen je jednačinom:

$$\overline{x}_k = \frac{1}{n} \sum_{i=k-n+1}^k x_i \quad (14)$$

Slično tome, u prethodnom vremenskom trenutku, $k-1$, prosjek posljednjih n uzoraka je:

$$\overline{x}_{k-1} = \frac{1}{n} \sum_{i=k-n}^{k-1} x_i \quad (15)$$


Prema tome, slijedi:

$$\overline{x}_k - \overline{x}_{k-1} = \frac{1}{n} \left[\sum_{i=k-n+1}^k x_i - \sum_{i=k-n}^{k-1} x_i \right] = \frac{1}{n} [x_k - x_{k-n}] \quad (16)$$

Nakon sređivanja dobijemo:

$$\overline{x}_k = \overline{x}_{k-1} + \frac{1}{n} [x_k - x_{k-n}] \quad (17)$$

To je poznato kao pomak vremenskih prozora, jer prosjek za svaki k trenutak temelji se na najnovijim n vrijednostima. Drugim riječima, za svaki trenutak, kretnje vrijednosti n se koriste za računanje prosjeka niza podataka (slika 4.1.).



Slika 4.1. Kretanje n niza podataka

Kada se koristi kao filter, vrijednost \overline{x}_k uzima se kao filtrirana vrijednost od x_k . Izraz je rekurzivan jer se vrijednost \overline{x}_k računa uz pomoć prethodne vrijednosti \overline{x}_{k-1} .

U usporedbi s osrednjavajućim filtrom, možemo vidjeti da nam treba samo jedna operacija dijeljenja, jedna operacija oduzimanja i zbrajanja. To je uvijek slučaj, bez obzira koliko

broja podatak (n) imamo. Međutim, računanje trenutne filtrirane vrijednosti zahtjeva korištenje x_{k-n} , tj. mjerenje n vremenskih koraka u prošlost. To znači da filtriranje ne može početi pouzdano dok se ne napravi n mjerenja. [9]

4.2 Osrednjavajući fliter s eksponencijalno opadajućim težinskim koeficijentom

Osrednjavajući filter s pomičnim vremenskim prozorom odnosi se prema svakoj vrijednosti s jednakom važnosti. Naime, u dinamičkim sustavima trenutne vrijednosti nastoje održati bolje stanje procesa pa bi filter koji stavlja veći naglasak na novije podatke bio korisniji. Takav filter može biti napravljen ako se koristi sljedeći postupak. Kao i prije, početna točka je prosječna vrijednost:

$$\overline{x}_k = \frac{1}{n} \sum_{i=k-n+1}^k x_i \quad (18)$$

Ali u ovom slučaju uzet ćemo još jednu dodatnu točku.

$$\overline{x}_{k+1} = \frac{1}{n} \sum_{i=k-n+1}^{k+1} x_i = \frac{1}{n} [x_{k+1} + \sum_{i=k-n+1}^k x_i] \quad (19)$$

Pošto je:

$$\sum_{i=k-n+1}^k x_i = n\overline{x}_k \quad (20)$$

Slijedi:

$$\overline{x}_{k+1} = \frac{1}{n+1} [x_{k+1} + nx_k] = \left(\frac{1}{n+1}\right) x_{k+1} + \left(\frac{n}{n+1}\right) \overline{x}_k \quad (21)$$

Pomicanjem indexa za jedan vremenski korak dobijemo izraz:

$$\overline{x}_k = \left(\frac{1}{n+1}\right) x_k + \left(\frac{n}{n+1}\right) \overline{x}_{k-1} \quad (22)$$

Da bi pojednostavili, $\alpha = \frac{n}{n+1}$ pa možemo pisati:

$$\overline{x}_k = (1 - \alpha)x_k + \alpha\overline{x}_{k-1} \quad (23)$$

Taj izraz opisuje ovakav filter. Kada se koristi kao filter, vrijednost \overline{x}_k je ponovno uzeta kao filtrirana vrijednost od x_k . Možemo primijetiti da proračun \overline{x}_k sada ne zahtjeva spremanje

prošlih vrijednosti x i od računskih operacija samo je potrebno jedno zbrajanje, jedno oduzimanje i dvije operacije množenja.

Vrijednost konstante filtra α određuje stupanj filtra, tj. jačini filtriranja tog filtra. Pošto $n \geq 0$, to znači da $0 \leq \alpha < 1$.

Kada je n veliki broj, odnosno kada imamo puno mjerenja, $\alpha \rightarrow 1$, i $\bar{x}_k \rightarrow \bar{x}_{k-1}$. To nam govori da je stupanj filtriranja toliko velik da mjerenje ne igra veliku ulogu u proračunu prosjeka. S druge strane, ako je $n \rightarrow 0$, onda $\bar{x}_k \rightarrow x_k$ to znači da se ne obavlja filtriranje. Ovaj filter stavlja veću važnost novijim podacima tako da odbacuje stare podatke eksponencijalno. Pošto je:

$$\bar{x}_k = (1 - \alpha)x_k + \alpha\bar{x}_{k-1} \quad (24)$$

onda je:

$$\bar{x}_k = (1 - \alpha)x_{k-1} + \alpha\bar{x}_{k-2} \quad (25)$$

Stoga:

$$\bar{x}_k = (1 - \alpha)x_k + \alpha\bar{x}_{k-1} = \alpha[\alpha\bar{x}_{k-2} + (1 - \alpha)x_{k-1}] + (1 - \alpha)x_k \quad (26)$$

$$\bar{x}_k = \alpha^2\bar{x}_{k-2} + \alpha(1 - \alpha)x_{k-1} + (1 - \alpha)x_k \quad (27)$$


Ali:

$$\bar{x}_{k-2} = \alpha\bar{x}_{k-3} + (1 - \alpha)x_{k-2} \quad (28)$$

Stoga je:

$$\begin{aligned} \bar{x}_k &= \alpha^2[\alpha\bar{x}_{k-3} + (1 - \alpha)x_{k-2}] + \alpha(1 - \alpha)x_{k-1} + (1 - \alpha)x_k = \\ &= \alpha^3\bar{x}_{k-3} + \alpha^2(1 - \alpha)x_{k-2} + \alpha(1 - \alpha)x_{k-1} + (1 - \alpha)x_k \end{aligned} \quad (29)$$

Ako nastavimo proširivati vrijednost \bar{x}_k s desne strane, vidjet ćemo da se vrijednost x_i povećava za potenciju od α . Pošto je α manje od 1, vrijednost x_i postaje progresivno manja. Težine od x_i može se predstaviti grafički (slika 4.2.):



Slika 4.2. Eksponencijalni rast težina

To znači da je u izračunatim filtriranim vrijednostima viši naglasak na novija mjerenja. Ovaj filter se najčešće koristi za smanjivanje šuma u industrijskim procesima. [9]

5 Metode uklanjanja smetnji sa signala


Najčešći tipovi smetnji su serijske (superponirane) smetnje na ulazu i smetnje uslijed zajedničkog potencijala mjernih stezaljki. Utjecaj serijskih smetnji umanjuje se izborom pravilnog mjernog uređaja (jedinice napajanja) i filtriranjem. Ukoliko su superponirane smetnje uzrokovane tijekom napajanja mjernog uređaja preko mrežnog napajnog ispravljača, možemo razmotriti primjenu baterijskog napajanja. Smetnje na ulazu uslijed zajedničkog potencijala mjernih stezaljki su česte u mjernoj tehnici. One nastaju uslijed elektromagnetskih smetnji koje se induciraju na priključnim vodičima. Otklanjaju se postavljanjem diferencijalnog pojačala u ulazni krug mjernog uređaja. S druge strane, šum u mjernim signalima može biti posljedica korištenja neadekvatne opreme, odnosno opreme ograničenih performansi. U toj skupini izvora mjernog šuma naročito se ističe takozvani kvantizacijski šum, opisan u poglavlju 2.2.

Smetnje koje se nisu mogle ukloniti prethodno navedenim postupcima potrebo je ukloniti naknadnom obradom signala. Jedan od najčešćih načina je filtriranje signala, koristeći jedan od filtra koji su prethodno opisani.

Kod mnogih eksperimenata pravi signal sa svojom vrijednosti amplitude (y os) mijenja se „glatko“ kao funkcija vrijednosti x-osi, dok se puno smetnji pojavljuje kao brze, slučajne promjene amplitude od točke do točke signala. U nekim situacijama korisno je smanjiti smetnje zaglađivanjem signala. Kod zaglađivanja, određene vrijednosti signala su promijenjene tako da vrijednosti signala koje su veće od susjednih (vjerojatno zbog šuma) smanjimo, a vrijednosti signala koje su niže od susjednih povećamo. Time dobivamo „gladi“ signal.


6 Sinteza filtera primjenom vremenskih prozora

Slika 6.1. pokazuje frekvencijski odziv idealnog niskopropusnog filtra. Sve frekvencije ispod odrezane frekvencije, f_c , propuštaju se s jediničnom amplitudom, a sve više frekvencije se ne propuštaju. Propusno područje je idealno ravno.



Slika 6.1. Frekvencijski odziv idealnog niskopropusnog filtra

Izračunamo li inverznu Fourierovu transformaciju ovog idealnog frekvencijskog odziva dobit ćemo idealni impulsni odziv prikazan na slici 6.2.



Slika 6.2. Impulsni odziv idealnog niskopropusnog filtra


Dobivena krivulja ima opći oblik: $\frac{\sin(x)}{x}$, određena izrazom:

$$h[i] = \frac{\sin(2\pi f_c i)}{i\pi} \quad (30)$$

Konvolucijom ulaznog signala s impulsnim odzivom signala dobije se idealan niskopropusni filter. Tada nastaje problem: *sinc* funkcija se nastavlja u negativnu i pozitivnu

beskonačnost bez slabljenja na nulu. U matematici, ovo protezanje u beskonačnost ne predstavlja problem, ali u praksi zaustavlja rad računala.


Kako bismo riješili taj problem, uvest ćemo dvije modifikacije *sinc* funkcije na slici 6.2., što rezultira valnim oblikom na slici 6.3.



Slika 6.3. Oblik signala nakon modifikacije

Prvo, funkcija je skraćena na $M+1$ točku, koje su odabrane simetrično oko glavnog loba, a M je paran broj. Svi ostali uzorci, izvan $M+1$ točaka, postavljaju se u nulu. Drugo, čitava sekvenca translatairana je desno, tako da počinje u 0, a završava u „ M “. Tako impulсни odziv prikazujemo korištenjem samo pozitivnih indeksa.


Budući da je modificirani impulсни odziv filtra samo aproksimacija idealnog impulsnog odziva, očito je da neće imati idealni frekvencijski odziv. Kako bi odredili frekvencijski odziv koji smo postigli možemo izvršiti Fourierovu transformaciju signala na slici 6.3., pa dobijemo krivulju prikazanu na slici 6.4.




Slika 6.4. Frekvencijski odziv modificiranog signala

Valoviti dio je prenaplašen u propusnom području, a lošije je i slabo u nepropusnom području. Problemi nastaju zbog naglih diskontinuiteta na rubovima skraćene *sinc* funkcije. Problemi se ne može riješiti produžimo li dužinu impulsnog signala filtra. Utjecaj diskontinuiteta ostaje značajan bez obzira na dužinu „ M “.


Jednostavan postupak može bitno popraviti situaciju. Slika 6.5. pokazuje glatko zakrivljenu krivulju nazvanu Blackmanov vremenski prozor. Pomnožimo li skraćenu funkciju sinc (slika 6.4.) s Blackmanovim vremenskim prozorom (slika 6.6.) rezultat impulsnog odziva filtra pokazuje slika 6.7.



Slika 6.5. Blackmanov vremenski prozor



Slika 6.6. Rezultat množenja Blackmanovog vremenskog prozora sa funkcijom sinc



Slika 6.7. Rezultat impulsnog odziva filtra

Ideja je ublažiti strmine skraćenih krajeva što poboljšava frekvencijski odziv. Slika 6.7. pokazuje to poboljšanje. Propusno područje je sada ravno.

Postoji veći broj vremenskih prozora, a dobili su imena po autorima u 1950-im godinama.[8]

7 Toplinska obrada

Toplinska obrada je postupak u kojem se predmet namjerno podvrgava temperaturno-vremenskim ciklusima kako bi se postigla željena mikrostruktura, a time i željena (mehanička, fizička, kemijska) svojstva. [1]


Toplinski se obrađuju najčešće čelici, ali često i drugi metali i keramike (staklo). Najčešći razlozi za toplinsku obradu čelika su očvršćivanje (povećanje mehaničkih svojstava, posebno vlačne čvrstoće), povećanje žilavosti, povećanje duktilnosti i mogućnosti preoblikovanja, smanjenje unutrašnjih naprezanja, priprema za obradu rezanjem.[7]

Toplinska se obrada obavlja:

- prije oblikovanja komada plastičnom deformacijom i odvajanjem strugotine, da bi metal omekšao
- poslije oblikovanja komada, da bi se uklonila zaostala naprezanja
- završno za postizanje konačne čvrstoće i tvrdoće proizvoda.

Vrste toplinskih obrada:

- termička: komadi se griju, drže na određenoj temperature i potom hlade, primjeri su:
 - žarenje – približavanje čelika stanju metastabilne ravnoteže
 - kaljenje
 - popuštanje – ugrijavanje kaljenog čelika na neku temperaturu ispod temperature austenizacije, držanjem na toj temperature, te sporim hlađenjem
 - poboljšanje – sastoji se od kaljenja, te visokotemperaturnog popuštanja s glavnim svrhom postizanja visoke granice tečenja i žilavosti
- toplinsko kemijski postupci: toplinska se obrada obavlja u kemijskoj aktivnoj sredini, primjeri su:
 - cementiranje – povećanje sadržaja ugljika u površinskom sloju; postizanje tvrdih površinskih slojeva strojnog dijela otpornih na trošenje, a da pritom jezgra strojnog dijela postigne što veću otpornost na udarna opterećenja
 - nitriranje – povećanje sadržaja dušika u površinskom sloju
 - karboniranje - povećanje sadržaja dušika i ugljika u površinskom sloju
 - boriranje - povećanje sadržaja bora u površinskom sloju
- termomehanička: termička obrada se kombinira s mehaničkim deformiranjem [7]



Slika 7.1. Dijagramski prikaz toplinske obrade [1]


ϑ_{TO} je temperatura toplinske obrade (općenito). Ugrijavanje i progrijavanje je trajanje do trenutka kada površinski slojevi postignu ϑ_{TO} , odnosno trajanje od trenutka ugrijavanja površine do trenutka kada i slojevi jezgre postignu ϑ_{TO} . Držanje je trajanje boravka predmeta na ϑ_{TO} od trenutka kada je on progrijan do početka ohlađivanja. Ohlađivanje je trajanje snižavanja temperature predmeta sve dok slojevi jezgre ne dostignu zadanu temperaturu, tj. izjednače je s temperaturom površinskih slojeva i okoliša. [1]

7.1 Kaljivost čelika

Kaljivost čelika je svojstvo čelika da se gašenjem s temperature austenitizacije zakali (postigne što veću tvrdoću na površini) i prokali (postigne što jednoličniju tvrdoću na poprečnom presjeku). [1]

7.1.1 Zakaljivost čelika

Zakaljivost čelika je viša što je veći sadržaj ugljika koji sudjeluje u procesu zakaljivanja. To se vidi iz Burnsova dijagrama (slika 7.2.). Onaj dio ugljika koji je ostao spojen u karbide nije otopljen pa kao karbid ne utječe na zakaljivost, a čak snižava prokaljivost.




Slika 7.2. Burnsov dijagram maksimalne postizive tvrdoće zakaljenih čelika u ovisnosti o udjelu ugljika[1]

7.1.2 Prokaljivost čelika

Termodinamika i iskustvo nam pokazuju da se pri gašenju čelika najintenzivnije hlade površinski slojevi, najmanje intenzivno hlade slojevi u jezgri presjeka, te da će intenzivnost hlađenja slojeva biti tim manja što su promjer i debljina strojnog dijela veća. Također, intenzivnost hlađenja ovisi u kojem se sredstvu ohlađuje strojni dio. Najintenzivnije hlađenje je u slanoj vodi, a najmanje intenzivno na mirnom zraku.

Ako bi se kaljeni valjci različitog promjera prerezali okomito na svoje osi, pa ako bi se izmjerile tvrdoće na tim poprečnim presjecima, dobio bi se raspored tvrdoća prikazan na slici 7.3.



Slika 7.3. Utjecaj dimenzija čeličnog predmeta na njegovu prokaljenost[1]

Kod predmeta promjera $\varnothing 10\text{ mm}$ postiglo se potpuno prokaljenje, a kod predmeta promjera $\varnothing 30\text{ mm}$ i $\varnothing 50\text{ mm}$ samo djelomično prokaljenje. Prema tome možemo zaključiti da će prokaljivost čelika biti bolja ako je kaljeni predmet manjih dimenzija i ako je primijenjeno intenzivnije hlađenje.

Kaljivost čelika se sastoji od zakaljivosti i prokaljivosti. Zakaljivost ovisi o udjelu ugljika u čeliku, prokaljivost ovisi o kemijskom sastavu čelika, a prokaljenost nekog strojnog dijela ovisi i o njegovim dimenzijama, te o intenzivnosti gašenja. [1]

8 Prikupljanje i procjena podataka u eksperimentu kaljenja

Izravno mjerenje temperature je neophodno za stjecanje znanja o procesu kaljenja. To je preduvjet za primjenu znanstvenih metoda u području koje je više empirijska tehnika. Ipak, iz mnogih razloga, to je predstavlja težak problem pri mjerenju.

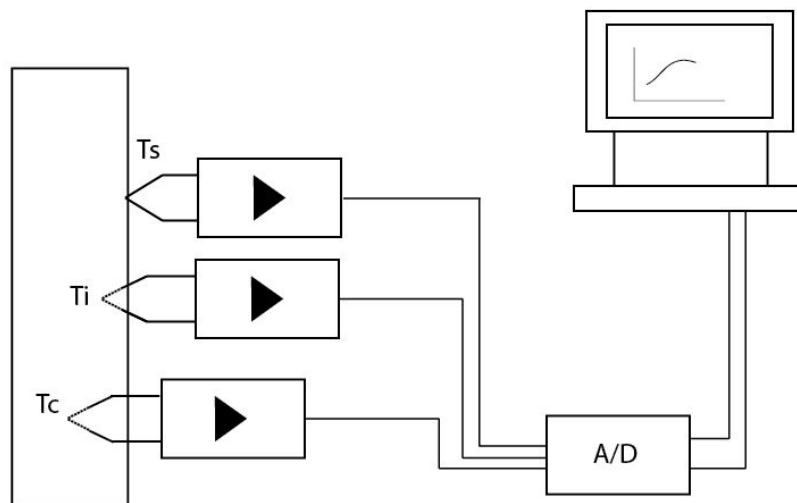
Jedan od problema je sama konstrukcija sonde zbog visokih temperatura (oko 1000 °C), brzih temperaturnih promjena, potreban je senzor koji ima brzi odziv.

Drugo, tu su poteškoće u stjecanju i ocjenjivanju podataka koji dobijemo od takve sonde, iz sljedećih razloga:

1. Velika razina elektromagnetskih smetnji u radnom okruženju, dok je nizak izlazni napon termopara.
2. Tu su i dodatni poremećaji iz raznih razloga, kao što su promjene u brzini hlađenja, utjecaj mjehura u tekućim medijima, itd.
3. Pošto je promjena temperature vrlo brza na početku eksperimenta, a poslije kako proces nastavlja sve sporija i sporija, podaci su prikupljeni sa promjenjivom stopom uzrokovanja. To čini ocjenjivanje takvih podataka znatno teže.
4. Budući da su funkcije ulaznih podatka računaju kao razlika temperature između dvije točke (osim toplinskog toka), pa se pogreške vrlo lako primjećuju.

8.1 Mjerni sustav

Kako bi se pratio proces hlađenja, sukladno metodi temperaturnog gradijenta, sonda zagrijana na oko 1000 °C se uroni u medij za hlađenje. Sama sonda je opremljena sa 3 termopara (slika 8.1.).



Slika 8.1. Mjerni sustav

Termoparovi su smješteni radialno na sredini duljine poprečnog presjeka u cilindričnoj sondi, gdje slijedi:

- prvi termopar (T_s) se nalazi nekoliko milimetara ispod površine
- drugi termopar (T_i) se nalazi na površini sonde
- treći termopar (T_c) se nalazi u centru sonde.

Termoparovi su spojeni na pojačalo. Pojačalo ima sljedeće zadatke:

- pojačanje ulaznog napona od nekih 40 mV do 10 V u punom opsegu A/D pretvarač
- filtriranje šumova

Funkcije koje možemo izračunati iz takvog mjernog sustava zahtijevaju analogno-digitalnu pretvorbu s najmanje 8 bita rezolucije i mogućnost uzimanja 100 uzoraka po sekundi ili manje. Takva izvedba A/D pretvornika je priključena na osobno računalo koji je opremljen sa grafičkim zaslonom visoke rezolucije i memorijom za pohranu podataka.

8.2 Obrada sirovih podataka

Budući da je proces hlađenja puno intenzivniji u početku (od uranjanja, trenutak kada je $t = 0$), podaci se prikupljaju sa nekoliko perioda uzorkovanja. Cijelo vrijeme hlađenja (oko 1000 sek) je podijeljeno na nekoliko intervala sa konstantnom periodom uzorkovanja. Ako je medij za hlađenje voda ili ulje uobičajno je uzeti period uzorkovanja od nekih 100 uzorka/sek, dok za zadnji inteval oko 1 uzorak/sek. Kada je eksperiment gotov vremena i temperature se spremaju u memoriju.

Sirovi podaci imaju puno šuma. Budući da bi daljnji proračun s takvim podacima dao besmislene rezultate, potrebna je neka vrsta obrade tih podataka. Ako se ta obrada podataka radi uz eksperiment onda ta obrada neće trajati dugo.

U eksperimentu se primjenjuje osrednjavajući način filtriranja temperatura koji je opisan u poglavlju 4.

Sve funkcije ćemo simulirati u programskom paketu MatLAB, kod takvoga programa dodan je u prilogu.

8.3 Proračun funkcija

Postoji niz funkcija koje su zanimljive za prikazati u eksperimentu kaljenja:

1. Temperatura – vrijeme
2. Razlika temperatura – vrijeme
3. Gustoća toplinskog toka – vrijeme
4. Gustoća toplinskog toka – temperatura površine
5. Integral gustoće toplinskog toka – vrijeme
6. Brzina hlađenja – vrijeme
7. Brzina hlađenja – temperatura površine


8.4 Rezultati ispitivanja

Da bi prikazali efikasnost gore navedene metode predstaviti ćemo rezultate eksperimenta. Za prvi i drugi dio eksperimenta korištena je cilindrična sonda sa tri termopara. Za prvi dio eksperimenta medij za hlađenje je kelanol 22s, brzina $v = 0 \text{ m/s}$, temperatura je $T = 20 \text{ °C}$. Kelanol su ulja za toplinsku obradu metala. Sastavom su prilagođena specifičnim uvjetima termičke obrade metala, oplemenjena dodacima za sprečavanje oksidacije i starenja kod visokih temperatura koja su prihvatljivija za okoliš jer ne sadrže barij.


Za drugi dio eksperimenta koristiti ćemo polimer (polymer sol. UCON quenchant E, 25%) kao medij za hlađenje, brzina $v = 0.8 \text{ m/s}$, temperatura je $T = 40 \text{ °C}$.

Slika 8.2. i 8.3. nam prikazuje ovisnost temperature o vremenu gdje je medij hlađenja ulje, odnosno polimer. Možemo zaključiti da je najveća temperatura u centru.

$$T = f(t) \quad (31)$$



Slika 8.2. Temperatura – vrijeme (ulje)




Slika 8.3. Temperatura – vrijeme (polimer)

Slika 8.4. i 8.5. prikazuju razlike temperatura između centra, ispod površine i na samoj površini. Najveća razlika temperatura je između centra sonda i površine, a najmanje između površine i nekoliko milimetara ispod površine.


$$T_c - T_i = f(T) \quad (32)$$

$$T_c - T_s = f(t) \quad (33)$$

$$T_i - T_s = f(t) \quad (34)$$



Slika 8.4. Razlika temperatura – vrijeme (ulje)



Slika 8.5. Razlika temperatura – vrijeme (polimer)


Slike 8.6. i 8.7. pokazuju ovisnost gustoće toplinskog toka o vremenu.

$$q_{is}, q_{ic} = f(t) \quad (35)$$


$$q_{is} = \lambda * \left| \frac{T_i - T_s}{r_i - r_s} \right| \left[\frac{W}{m^2} \right] \quad (36)$$

$$q_{ic} = \lambda * \left| \frac{T_i - T_c}{r_i - r_c} \right| \left[\frac{W}{m^2} \right] \quad (37)$$

gdje je $\lambda \left[\frac{W}{mK} \right]$ toplinska vodljivost i ona je varijabilna s temperaturom, a $r [m]$ je radijalna udaljenost od termopara do centra sonde.




Slika 8.6. Gustoća toplinskog toka – vrijeme (ulje)




Slika 8.7. Gustoća toplinskog toka – vrijeme(polimer)

Slika 8.8. i 8.9. nam pokazuju ovisnost gustoće toplinskog toka o temperaturi površine. Gustoću toplinskog toka računamo prema gore navednim formulama za q_{is} i q_{ic} .

$$q_{is}, q_{ic} = f(T) \quad (38)$$




Slika 8.8. Gustoća toplinskog toka – temperatura površine (ulje)




Slika 8.9. Gustoća toplinskog toka – temperatura površine (polimer)

Slike 8.10. i 8.11. prikazuju ovisnost integrala gustoće toplinskog toka o vremenu.

$$\int q_{is}, \int q_{ic} = f(t) \quad (39)$$




Slika 8.10. Integral gustoće toplinskog toka – vrijeme (ulje)




Slika 8.11. Integral gustoće toplinskog toka – vrijeme(polimer)

Slike 8.12. i 8.13. prikazuju ovisnost brzine hlađenja o vremenu. Na ovim slikama možemo primjetiti teže očitavanje podatka, pa bi nam najbolje bili filtrirati ove grafove za kvalitetnije očitavanje podatka.

$$\frac{dT_c}{dt}, \frac{dT_s}{dt}, \frac{dT_i}{dt} = f(t) \quad (40)$$




Slika 8.12. Brzina hlađenja – vrijeme (ulje)




Slika 8.13. Brzina hlađenja – vrijeme (polimer)

Slike 8.14. i 8.15. prikazuju kako brzina hlađenja ovisi o temperaturi površine. I na ovim slikama također teže čitamo podatke, te bi ove grafove trebalo filtrirati.

$$\frac{dT_c}{dt}, \frac{dT_s}{dt}, \frac{dT_i}{dt} = f(T_s) \quad (41)$$



Slika 8.14. Brzina hlađenja – temperatura površine (ulje)



Slika 8.15. Brzina hlađenja – temperatura površine (polimer)

8.5 Filtriranje rezultata

Pošto se u sirovim signalima pojavljuje šumovi, koji nam otežavaju čitanje rezultata, koristiti ćemo filtre koji će smanjiti šumove i prikazati kvalitetne rezultate.


8.5.1 Odabir metode filtriranja

Kako bi izabrali najbolju metodu filtriranja na Heaviside (step) funkciji testirati ćemo metode filtriranja, te ćemo sistemom eliminacije izabrati onu koja ima najbolji odziv. To ćemo simulirati u programskom paketu „MatLAB“.

Metode filtriranja koje ćemo uspoređivati su:


- Bartlett window
- Bartlett–Hann window
- Blackman window
- Blackman–Harris window
- Bohman window
- Chebyshev window
- Flat top window
- Gaussian window
- Hamming window
- Hann window
- Kaiser window
- Nuttall window
- Parzen window
- Rectangular window
- Tukey window
- Triangular window

Prvo ćemo podijeliti metode filtriranja u četiri skupine, te ćemo tražiti najbolju metodu iz tih skupina. Najbolja je ona koja ima najbrži odziv bez nadvišenja, uz istovremeno najbolje potiskivanje utjecaja šuma u danoj skupini, karakteriziranoj identičnim širinama vremenskog prozora za svaki promatrani filter. Na kraju ćemo najbolje metode iz svake skupine usporediti i izabrati najbolju, te ćemo tom metodom filtrirati sirove rezultate (slika 8.16.).



Slika 8.16. Odabir metode filtriranja


Prvu skupinu čine četiri metode: Bartlett, Bartlett-Hann, Blackman i Blackman-Harris window.



Slika 8.17. Prva skupina metoda filtriranja

Najbolja metoda od četiri navedene je: Blackman-Harris window. Ova metoda ima najbrži odziv.


Sljedeću skupinu metoda filtriranja čine: Bohman window, Chebyshev window, Flat top window i Gaussian window.



Slika 8.18. Druga skupina metoda filtriranja

Najbolja metoda od ovih je: Chebyshev window. Ova metoda ima najbrži odziv i ne dolazi do nadvišenja.


Sljedeće četiri metode su: Hamming window, Hann window, Kaiser window i Nuttall window.



Slika 8.19. Treća skupina metoda filtriranja

Najbolja metoda od metoda prikazanih na slici je: Nuttall window. Ona je najbolja jer ima najbrži odziv i ne dolazi do nadvišenja.


Zadnja skupina metode filtriranja čine: Parzen window, Rectangular window, Tukey window, Triangular window.



Slika 8.20. Četvrta skupina metoda filtriranja

Najbolja metoda filtriranja od ovih je: Parzen window. Ova metoda ima najbrži odziv od ostalih.

Sada ćemo usprediti četiri najbolje metode iz svake skupine te izabrati onu s kojom ćemo filtrirati sirove rezultate. Metode koje ćemo uspoređivati su: Parzen window, Nuttall window, Chebyshev window i Blackman–Harris window.




Slika 8.21. Najbolje metode filtriranja

Metodu koju ćemo koristiti za filtriranje podataka je „Chebyshev window“. Ova metoda ima najbrži odziv, te ne dolazi do nadvišenja, pa je ujedno i najbolja za filtriranje sirovih rezultata.


8.5.2 Filtriranje sirovih podataka

Koristeći „Chebyshev window“ metodu filtrirati ćemo sirove rezultate, pa ćemo moći kvalitetnije očitati rezultate. Sljedeće slike su filtrirani prvi dio eksperimeneta (gdje je medij za hlađenje ulje) i drugi (gdje je medij za hlađenje polimer).

Slike 8.22. 8.23. prikazuju ovisnost temperature o vremenu gdje je medij hlađenja ulje za prvi sliku i polimer za drugu sliku, ali ove slike su filtrirane. Možemo primjetiti ako usporedimo ove slike sa slikama 8.2. i 8.3. da nema pretjerane razlike u slikama. Razlog tome je što su podaci interpolirani, te ne dolazi do velikog odstupanja sirovih podataka od filtriranih.




Slika 8.22. Temperatura – vrijeme (ulje, filtrirano)




Slika 8.23. Temperatura – vrijeme (polimer, filtrirano)

Slike 8.24. i 8.25. nam pokazuju ovisnost razlike temperatura o vremenu gdje je medij hlađenja ulje i polimer, ali ovoga puta filtrirano. Također, ako usporedimo sa slikama 8.4. i 8.5. vidimo da nema pretjerane razlike u grafovima. Razlog tome je isti kao i na predhodnim slikama, podaci su interpolirani, te je primjenjena jednostavna operacija oduzimanja, i ne dolazi do odstupanja filtriranih podataka od izvornih.




Slika 8.24. Razlika temperatura – vrijeme (ulje, filtrirano)




Slika 8.25. Razlika temperatura – vrijeme (polimer, filtrirano)

Slike 8.26. i 8.27. nam pokazuju ovisnost gustoće toplinskog toka o vremenu gdje je medij hlađenja ulje i polimer, ali ovoga puta filtrirano. Ako usporedimo sa slikama 8.6. i 8.7. vidimo da su filtrirane krivulje glađe.




Slika 8.26. Gustoća toplinskog toka – vrijeme (ulje, filtrirano)




Slika 8.27. Gustoća toplinskog toka – vrijeme (polimer, filtrirano)

Slike 8.28. i 8.29. nam pokazuju ovisnost gustoće toplinskog toka o temperaturi površine (medij hlađenja ulje i polimer), ali ovoga puta isto filtrirano. Usporedbom sa slikama 8.8. i 8.9. možemo vidjeti da su filtrirani grafovi gladi od izvornih.




Slika 8.28. Gustoća toplinskog toka – temperatura površine (ulje, filtrirano)




Slika 8.29. Gustoća toplinskog toka – temperatura površine (polimer, filtrirano)

Slike 8.30. i 8.31. nam pokazuju integral gustoće toplinskog toka u ovisnosti o temperaturi površine (medij hlađenja ulje i polimer), ali ovoga puta također filtrirano. Ove slike ne odstupaju od izvornih (slike 8.10. i 8.11.) pošto se primjenjuje računaska operacija integriranja, ne dolazi do velikih odstupanja.




Slika 8.30. Integral gustoće toplinskog toka – vrijeme (ulje, filtrirano)




Slika 8.31. Gustoća toplinskog toka – temperatura površine (polimer, filtrirano)

Slike 8.32. i 8.33. nam pokazuju filtrirane podatke brzine hlađenja u ovisnosti o vremenu kada je medij hlađenja ulje i polimer. Usporedbom ovih slika sa slikama 8.12. i 8.13. možemo primjetiti veću razliku u grafovima. Sa slike 8.12., odnosno 8.13. nismo mogli kvalitetno očitati podatke, te se tek korištenjem metode fitiranja podaci mogu bolje i kvalitetnije očitati.




Slika 8.32. Brzina hlađenja – vrijeme (ulje, filtrirano)




Slika 8.33. Brzina hlađenja – vrijeme (*polimer, filtrirano*)

Slike 8.34. i 8.35. nam pokazuju filtrirane podatke brzine hlađenja u ovisnosti o temperaturi površine kada je medij hlađenja ulje i polimer. Ako usporedimo ove slike sa slikama 8.14. i 8.15. možemo primjetiti kao i na prošlim slikama, da se podaci mogu kvalitetnije očitati. Jedino se manji šumovi pojavljuju na temperaturama iznad 800 °C. Razlog tome je što smo koristili 8 bitni konverter prilikom obrade podatka.



Slika 8.34. Brzina hlađenja – temperatura površine (*filtrirano*)



Slika 8.35. Brzina hlađenja – temperatura površine (filtrirano)

9 Zaključak

U završnom radu si prikazani rezultati obrade signala temperature prethodno snimljeni u procesu zakaljivanja, a koji su zbog ograničene rezolucije senzora (8-bitni zapis podatka) karakterizirani izraženim šumom kvantizacije.

Zbog izraženog šuma mjerenja u radu je bilo potrebno primijeniti postupke digitalne obrade signala primjenom digitalnih filtera koji na pred-definiranom vremenskom „prozoru“ (intervalu) računaju otežanu aritmetičku sredinu mjernih točaka.

U svrhu izbora najpogodnijeg filtera u smislu brzine odziva i potiskivanja šuma provedena je komparativna analiza 16 različitih osrednjavajućih filtera koja je rezultirala izborom osrednjavajućeg filtera sa vremenskim prozorom temeljenog na Čebiševljevoj polinomskoj krivulji.

Odabir filtra, kao i rutina za pripremu, dodatno procesiranje, računanje temperaturnih gradijenta i iscrtavanje konačnih rezultata implementirani su u programskom paketu MatLAB.

Usporedbom sirovih rezultata sa filtriranim možemo primijetiti bolji i kvalitetniji prikaz rezultata. Uklanjanjem šuma postigli smo kvalitetniju rekonstrukciju karakterističnih krivulja procesa zakaljivanja. Filtriranje nam je omogućilo pregledniji prikaz rezultata analize snimljenih podataka.

Dodatna unaprjeđenja ovoga rada su moguća. Ona mogu uključivati optimiranje širine prozora na kojem se vrši osrednjavanje, te primjene naprednih interpolacijskih filtera kao što je Savitzky-Golay filter.

Literatura

- [1] M. Stupnišek, F. Canjer: „Osnove toplinske obrade metala“, Fakultet strojarstva i brodogradnje Zagreb, Zagreb, 2001.
- [2] M. Essert, T. Žilić: „MATLAB – Matrični laboratorij“
- [3] Monson H. Hayes: „Digital signal processing“, McGraw-Hill, New York, 1999.
- [4] User's guide Signal Processing Toolbox For Use with MATLAB
- [5] Steven W. Smith: „The Scientist & Engineer's Guide to Digital Signal Processing“, California Technical Pub; 1st edition, 1997.
- [6] Steve White: „Digital Signal Processing: A Filtering Approach“, Delmar Cengage Learning, 2000.
- [7] Kaljenje, <http://hr.wikipedia.org/wiki/Kaljenje>, 2014.
- [8] Window function, http://en.wikipedia.org/wiki/Window_function#Rectangular_window, 2015.
- [9] Dealing with measurement noise, <http://lorien.ncl.ac.uk/ming/filter/filmav.htm>
- [10] D. Majetić: „Upravljanje i regulacije - skripta“, Fakultet strojarstva i brodogradnje, Zagreb
- [11] Teorem uzrokovanja, http://eskola.hfd.hr/pc_kut/tuzork/, 1999.
- [12] Digital filter design, <http://www.mikroe.com/chapters/view/71/chapter-1-basic-concepts-of-digital-filtering-and-types-of-digital-filters/>
- [13] Filter (signal processing), [http://en.wikipedia.org/wiki/Filter_\(signal_processing\)](http://en.wikipedia.org/wiki/Filter_(signal_processing))

Prilog: Listing Matlab koda softvera za obradu podataka zasnovanog na FIR filtrima

```
clear all
clc

pause(1)

echo on
%Evaluacija mjernih podataka zakaljivanja
%Završni rad: "Obrada eksperimentalnih podataka procesa zakaljivanja
%primjenom osrednjavajućih i interpolacijskih digitalnih filtara"
%Student: Hrvoje Pinculić
echo off
pause(1)
echo on
% Upute za korištenje:
% Ovaj program nam omogućuje prikaz razlicitih funkcija u eksperimentu
zakaljivanja.
% Za pocetak treba unijeti nacin hladenja: „1“ za kalenol ili „2“ za
polimer.
% Nakon toga moramo izabrati metodu filtriranja. Također je potrebno unijeti
broj između „1“ i „16“.
% Postoji i mogućnost da ostavimo prazan unos, pa će nam program automatski
izabrati najbolju metodu
% filtriranja (Chebyshev window). Kada smo odabrali metodu filtriranja
potrebno je odabrati i sirinu
% prozora. Možemo ostaviti i prazno, onda će program automatski postaviti
preporucenu vrijednost za
% sirinu prozora („500“). Zadnji unos nam daje na izbor funkciju koju želimo
prikazati.
% Za odabir funkcije trebamo unijeti broj između „1“ i „7“, a ako unesemo
broj „8“ izaci ćemo iz programa.

echo off

pause(1)

echo on

%Izbor nacina hladenja:
%1 - Kalenol
%2 - Polimer
echo off

data=0;
while ((data~=1) || (data~=2))

% Unos podataka
data=input('Nacin hladenja (1 - 2) = ');

switch data
    case 1
```



```
data='ulje';
data_file=strcat(data, '.txt');
break

case 2
    data='kelanol';
    data_file=strcat(data, '.txt');
    break

otherwise
    disp ('Nije zadovoljavajući izbor, izaberite ponovno!')

end
end

pause(1)

echo on

% Izbor prozora:

% 1 -> @bartlett      - Bartlett window.
% 2 -> @barthannwin   - Modified Bartlett-Hanning window.
% 3 -> @blackman      - Blackman window.
% 4 -> @blackmanharris - Minimum 4-term Blackman-Harris window.
% 5 -> @bohmanwin     - Bohman window.
% 6 -> @chebwin       - Chebyshev window.
% 7 -> @flattopwin    - Flat Top window.
% 8 -> @gausswin      - Gaussian window.
% 9 -> @hamming       - Hamming window.
% 10 -> @hann         - Hann window.
% 11 -> @kaiser       - Kaiser window.
% 12 -> @nuttallwin    - Nuttall defined minimum 4-term Blackman-Harris
window.
% 13 -> @parzenwin    - Parzen (de la Valle-Poussin) window.
% 14 -> @rectwin      - Rectangular window.
% 15 -> @tukeywin     - Tukey window.
% 16 -> @triang       - Triangular window.

echo off

% Izbor metode filtriranja

window_no = input('Tip prozora (1 - 16) = ');

if isempty(window_no), window_no = 6; end
window_no = round(window_no);

switch window_no
    case 1
        window_name = @bartlett;
    case 2
        window_name = @barthannwin;
    case 3
        window_name = @blackman;
```

```
case 4
    window_name = @blackmanharris;
case 5
    window_name = @bohmanwin;
case 6
    window_name = @chebwin;
case 7
    window_name = @flattopwin;
case 8
    window_name = @gausswin;
case 9
    window_name = @hamming;
case 10
    window_name = @hann;
case 11
    window_name = @kaiser;
case 12
    window_name = @nuttallwin;
case 13
    window_name = @parzenwin;
case 14
    window_name = @rectwin;
case 15
    window_name = @tukeywin;
case 16
    window_name = @triang;
otherwise
    window_name = @chebwin;
    disp ('Nije zadovoljavajući izbor, postavljen je: Chebyshev
window!');
end

pause(1)
N = input('Sirina prozora (> 1) N = ');

if isempty(N), N = 500; end
N = round(N);

pause(1)

echo on

% Izbor funkcije:

% 1 -> Prikaz ovisnosti temperatura o vremenu
% 2 -> Ovisnost razlika temperatura o vremenu
% 3 -> Gustoća toplinskog toka u ovisnosti o vremenu
% 4 -> Gustoća toplinskog toka u ovisnosti o temperaturi površine
% 5 -> Integral gustoće top. toka u ovisnosti o vremenu
% 6 -> Brzina hlađenja u ovisnosti o vremenu
% 7 -> Brzina hlađenja u ovisnosti o temperaturi površine
% 8 -> Kraj programa!

echo off

% INTERPOLACIJA
```

```

a = load(data_file);
t_exp = a(:,1);
t=0:0.01:t_exp(end);

Ts=interp1(a(:,1),a(:,2),t,'linear'); %Ts površina interpolirano
Ti=interp1(a(:,1),a(:,3),t,'linear'); % Ti interpolirano
Tc=interp1(a(:,1),a(:,4),t,'linear'); % Tc centar interpolirano

izbor=0;

while (izbor~=8)

izbor = input ('Izbor funkcije (1 - 8) = ');
if isempty(izbor), disp ('Nije zadovoljavajući izbor!'); end
izbor=round(izbor);

switch izbor

    case 1

close ('all')

figure(1)
semilogx(t(N:length(t)),Ts(N:length(Ts))),hold on;
semilogx(t(N:length(t)),Ti(N:length(Ti)),'--'),hold on;
semilogx(t(N:length(t)),Tc(N:length(Tc)),'Linewidth',2),
axis([0.1 1000 0 900]);
grid on
legend ('T površine', 'T -1,5 mm ispod površine', 'T u centru');
xlabel('vrijeme (s)');
ylabel('temperatura (°C)');
title ('Ovisnost temperature o vremenu');

% FIR (finite impulse response) filter ima samo B polinom
B = window(window_name,N);
% A polinom treba normirati kako bi stacionarno pojačanje filtra bilo jednako
jedinici
A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
filt_Ts = filter(B,A,Ts);
filt_Ti = filter(B,A,Ti);
filt_Tc = filter(B,A,Tc);

figure(2)
semilogx (t(N:length(t)), filt_Ts(N:length(filt_Ts))),hold on;
semilogx(t(N:length(t)), filt_Ti(N:length(filt_Ti)),'--'),hold on;
semilogx(t(N:length(t)), filt_Tc(N:length(filt_Tc)),'Linewidth',2)
axis([0.1 1000 0 900]);
grid on

```

```

legend ('T površine', 'T -1,5 mm ispod površine', 'T u centru');
xlabel('vrijeme (s)');
ylabel('temperatura (°C)');
title ('Ovisnost temperature o vremenu (filtrirano)');

```

```

case 2

```

```

close ('all')

```

```

delta_T1=abs(Tc-Ti);
delta_T2=abs(Tc-Ts);
delta_T3=abs(Ti-Ts);

```

```

figure (1)
semilogx (t(N:length(t)), delta_T1(N:length(delta_T1)),hold on;
semilogx(t(N:length(t)), delta_T2(N:length(delta_T2)), '--',hold on;
semilogx(t(N:length(t)), delta_T3(N:length(delta_T3)), 'Linewidth',2)
grid on
xlabel('vrijeme (s)');
ylabel('razlika temperatura (°C)');
legend ('Tc-Ti', 'Tc-Ts','Ts-Ti')
title ('Ovisnost razlika temperatura o vremenu')

```

```

% FIR (finite impulse response) filter ima samo B polinom
B = window(window_name,N);
% A polinom treba normirati kako bi stacionarno pojačanje filtra bilo jednako
jedinici
A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
filt_Ts = filter(B,A,delta_T1);
filt_Ti = filter(B,A,delta_T2);
filt_Tc = filter(B,A,delta_T3);

```

```

figure(2)
semilogx (t(N:length(t)), filt_Ts(N:length(filt_Ts)),hold on;
semilogx(t(N:length(t)), filt_Ti(N:length(filt_Ti)), '--',hold on;
semilogx(t(N:length(t)), filt_Tc(N:length(filt_Tc)), 'Linewidth',2)
grid on
xlabel('vrijeme (s)');
ylabel('razlika temperatura (°C)');
legend ('Tc-Ti', 'Tc-Ts','Ts-Ti')
title ('Ovisnost razlika temperatura o vremenu(filtrirano)')

```

```

case 3

```

```

close ('all')

```

```

LA=0.01354;
LB=10.53;

```

```

lambda1=LB+LA*((Ts+Ti)/2);
temp1=abs((Ts-Ti)/(-1.5));

```

```

qs15=(lambda1.*temp1);

lambda2=LB+LA*((Ts+Tc)/2);
temp2=abs((Ts-Tc)/(-25));
qsc=(lambda2.*temp2);

lambda3=LB+LA*((Ti+Tc)/2);
temp3=abs((Ti-Tc)/(-23.5));
qsc3=(lambda3.*temp3);

figure(1)
semilogx(t(N:length(t)),qs15(N:length(qs15))),hold on;
semilogx(t(N:length(t)),qsc(N:length(qsc)),'--'),hold on;
semilogx(t(N:length(t)),qsc3(N:length(qsc3)),'Linewidth',2)
axis ([1 1000 0 3000]);
grid on
xlabel('vrijeme (s)');
ylabel('gustoća toplinskog toka (kW/m^2)');
legend ('od površine do -1,5mm od površine', 'od površine do centra','od -
1,5mm od površine do centra');
title ('Gustoća toplinskog toka u ovisnosti o vremenu');

% FIR (finite impulse response) filter ima samo B polinom
B = window(window_name,N);
% A polinom treba normirati kako bi stacionarno pojačanje filtra bilo jednako
jedinici
A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
filt_qs15 = filter(B,A,qs15);
filt_qsc = filter(B,A,qsc);
filt_qsc3 = filter(B,A,qsc3);

figure(2)
semilogx (t(N:length(t)), filt_qs15(N:length(filt_qs15))),hold on;
semilogx (t(N:length(t)), filt_qsc(N:length(filt_qsc)),'--'),hold on;
semilogx (t(N:length(t)), filt_qsc3(N:length(filt_qsc3)),'Linewidth',2)
axis ([1 1000 0 3000]);
grid on
xlabel('vrijeme (s)');
ylabel('gustoća toplinskog toka (kW/m^2)');
legend ('od površine do -1,5mm od površine', 'od površine do centra','od -
1,5mm od površine do centra');
title ('Gustoća toplinskog toka u ovisnosti o vremenu (filtrirano)');

case 4

close ('all')

LA=0.01354;
LB=10.53;

lambda1=LB+LA*((Ts+Ti)/2);
temp1=abs((Ts-Ti)/(-1.5));
qs15=(lambda1.*temp1);

```

```

lambda2=LB+LA*((Ts+Tc)/2);
temp2=abs((Ts-Tc)/(-25));
qsc=(lambda2.*temp2);

lambda3=LB+LA*((Ti+Tc)/2);
temp3=abs((Ti-Tc)/(-23.5));
qsc3=(lambda3.*temp3);

figure(1)
plot (Ts(N:length(Ts)), qs15(N:length(qs15))), hold on;
plot (Ts(N:length(Ts)), qsc(N:length(qsc)), '--'), hold on;
plot (Ts(N:length(Ts)), qsc3(N:length(qsc3)), 'Linewidth',2)
axis ([0 1200 0 3000])
grid on
xlabel('temperatura površine (°C)');
ylabel('gustoća toplinskog toka (kW/m^2)');
legend ('od površine do -1,5mm od površine', 'od površine do centra', 'od -1,5mm od površine do centra');
title ('Gustoća toplinskog toka u ovisnosti o temperaturi površine');

% FIR (finite impulse response) filter ima samo B polinom
B = window(window_name,N);
% A polinom treba normirati kako bi stacionarno pojačanje filtra bilo jednako jedinici
A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
filt_qs15 = filter(B,A,qs15);
filt_qsc = filter(B,A,qsc);
filt_qsc3 = filter(B,A,qsc3);

figure(2)
plot (Ts(N:length(Ts)), filt_qs15(N:length(filt_qs15))), hold on;
plot (Ts(N:length(Ts)), filt_qsc(N:length(filt_qsc)), '--'), hold on;
plot (Ts(N:length(Ts)), filt_qsc3(N:length(filt_qsc3)), 'Linewidth',2)
axis ([0 1200 0 3000])
grid on
xlabel('temperatura površine (°C)');
ylabel('gustoća toplinskog toka (kW/m^2)');
legend ('od površine do -1,5mm od površine', 'od površine do centra', 'od -1,5mm od površine do centra');
title ('Gustoća toplinskog toka u ovisnosti o temperaturi površine(filtrirano)');

case 5

close ('all')

LA=0.01354;
LB=10.53;
lambda1=LB+LA*((Ts+Ti)/2);
temp1=abs((Ts-Ti)/(-1.5));
qs15=(lambda1.*temp1)/1000;

lambda2=LB+LA*((Ts+Tc)/2);
temp2=abs((Ts-Tc)/(-25));

```

```

qsc=(lambda2.*temp2)/1000;

lambda3=LB+LA*((Ti+Tc)/2);
temp3=abs((Ti-Tc)/(-23.5));
qsc3=(lambda3.*temp3)/1000;

intqs15=cumtrapz(t,qs15);
intqsc=cumtrapz(t,qsc);
intqsc3=cumtrapz(t,qsc3);

figure(1)
semilogx(t(N:length(t)), intqs15(N:length(intqs15))),hold on;
semilogx(t(N:length(t)), intqsc(N:length(intqsc)),'--'),hold on;
semilogx(t(N:length(t)), intqsc3(N:length(intqsc3)),'Linewidth',2)
grid on
% axis ([1 1000 0 100])
xlabel('vrijeme (s)');
ylabel('integral gustoće top. toka (MWs/m^2)');
legend ('od površine do -1,5mm od površine', 'od površine do centra','od -
1,5mm od površine do centra')
title ('Integral gustoće toplinskog toka u ovisnosti o vremenu')

% FIR (finite impulse response) filter ima samo B polinom
B = window(window_name,N);
% A polinom treba normirati kako bi stacionarno pojaćanje filtra bilo jednako
jedinici
A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
filt_qs15 = filter(B,A,intqs15);
filt_qsc = filter(B,A,intqsc);
filt_qsc3 = filter(B,A,intqsc3);

figure(2)
semilogx(t(N:length(t)), filt_qs15(N:length(filt_qs15))),hold on;
semilogx(t(N:length(t)), filt_qsc(N:length(filt_qsc)),'--'),hold on;
semilogx(t(N:length(t)), filt_qsc3(N:length(filt_qsc3)),'Linewidth',2)
grid on
% axis ([1 1000 0 100])
xlabel('vrijeme (s)');
ylabel('integral gustoće top. toka (MWs/m^2)');
legend ('od površine do -1,5mm od površine', 'od površine do centra','od -
1,5mm od površine do centra')
title ('Integral gustoće toplinskog toka u ovisnosti o vremenu(filtrirano)')

case 6

close ('all')

% FILTRIRANJE

% FIR (finite impulse response) filter ima samo B polinom
B = window(@rectwin ,N);
% A polinom treba normirati kako bi stacionarno pojaćanje filtra bilo jednako
jedinici

```

```

A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
yc = (filter(B,A,Tc));
yi = (filter(B,A,Ti));
ys = (filter(B,A,Ts));

%DERIVACIJA

dc_filt=abs(diff(yc)./diff(t)); %derivacija dTc/dt
di_filt=abs(diff(yi)./diff(t)); %derivacija dTi/dt
ds_filt=abs(diff(ys)./diff(t)); %derivacija dTs/dt

figure(1)
semilogx (t(N:length(t)-1), dc_filt(N:length(dc_filt))), hold on;
semilogx (t(N:length(t)-1), di_filt(N:length(di_filt)), '--'), hold on;
semilogx (t(N:length(t)-1), ds_filt(N:length(ds_filt)), 'Linewidth',2)
grid on
xlabel('vrijeme (s)');
ylabel('brzina hlađenja (°C/s)');
legend ('u centru', '-1.5mm od površine', 'na površini');
title ('Brzina hlađenja u ovisnosti o temperaturi površine(filtrirano)');

dc=abs(diff(Tc)./diff(t)); %derivacija dTc/dt
di=abs(diff(Ti)./diff(t)); %derivacija dTi/dt
ds=abs(diff(Ts)./diff(t)); %derivacija dTs/dt

figure(2)
semilogx (t(N:length(t)-1), dc(N:length(dc))), hold on;
semilogx (t(N:length(t)-1), di(N:length(di)), '--'), hold on;
semilogx (t(N:length(t)-1), ds(N:length(ds)), 'Linewidth',2)
grid on
xlabel('vrijeme (s)');
ylabel('brzina hlađenja (°C/s)');
legend ('u centru', '-1.5mm od površine', 'na površini');
title ('Brzina hlađenja u ovisnosti o temperaturi površine');

case 7

close ('all')

% FILTRIRANJE

% FIR (finite impulse response) filter ima samo B polinom
B = window(@rectwin ,N);
% A polinom treba normirati kako bi stacionarno pojačanje filtra bilo jednako
jedinici
A = [sum(B) zeros(1, N-1)];
% Unaprijedni (jednosmjerni / kauzalni) filter
yc = (filter(B,A,Tc));
yi = (filter(B,A,Ti));
ys = (filter(B,A,Ts));

%DERIVACIJA

dc_filt=abs(diff(yc)./diff(t)); %derivacija dTc/dt
di_filt=abs(diff(yi)./diff(t)); %derivacija dTi/dt

```



```
ds_filt=abs(diff(ys)./diff(t)); %derivacija dTs/dt

figure(1)
plot (Ts(N:length(Ts)-1), dc_filt(N:length(dc_filt))), hold on;
plot (Ts(N:length(Ts)-1), di_filt(N:length(di_filt)), '--'), hold on;
plot (Ts(N:length(Ts)-1), ds_filt(N:length(ds_filt)), 'Linewidth',2)
grid on
xlabel('temperatura (°C)');
ylabel('brzina hlađenja (°C/s)');
legend ('u centru', '-1.5mm od površine', 'na površini');
title ('Brzina hlađenja u ovisnosti o temperaturi površine (filtrirano)');

dc=abs(diff(Tc)./diff(t)); %derivacija dTc/dt
di=abs(diff(Ti)./diff(t)); %derivacija dTi/dt
ds=abs(diff(Ts)./diff(t)); %derivacija dTs/dt

figure(2)
plot (Ts(N:length(Ts)-1), dc(N:length(dc))), hold on;
plot (Ts(N:length(Ts)-1), di(N:length(di)), '--'), hold on;
plot (Ts(N:length(Ts)-1), ds(N:length(ds)), 'Linewidth',2)
grid on
xlabel('temperatura (°C)');
ylabel('brzina hlađenja (°C/s)');
legend ('u centru', '-1.5mm od površine', 'na površini');
title ('Brzina hlađenja u ovisnosti o temperaturi površine');

    case 8
        close ('all')
        disp('Kraj programa!');

    otherwise

disp ('Nije zadovoljavajući izbor!');

end
end
```